

# 基于径向基小波网络的二代棉铃虫卵峰日预测模型

朱军生<sup>1,2</sup>, 翟保平<sup>1,\*</sup>, 董保信<sup>2</sup>

(1. 南京农业大学昆虫学系, 南京 210095; 2. 山东省植物保护总站, 济南 250100)

**摘要:** 为了提高害虫预报的准确率, 将径向基小波网络首次引入农作物害虫预测预报领域, 改进了径向基小波网络的学习算法, 使之适合于害虫预测的应用: 利用径向基小波函数族时、频两域支撑完全或部分覆盖被分析数据序列时、频两域支撑的原理来确定小波函数族尺度参数和平移参数取值; 根据中心向量之间的欧式距离大小来初步筛选隐含层神经元。在实例分析中, 本文利用 1966–1995 年山东省惠民县棉铃虫 *Helicoverpa armigera* 的监测数据建立了基于径向基小波网络的 2 代棉铃虫卵量峰值日期预测模型, 利用 1996–2000 年的监测数据对模型进行了检验。检验结果表明: 在 5 年的预测数据中, 4 年的预测数据偏差在 3 d 以内, 另外 1 年的预测数据偏差 4 d, 预测效果令人满意。本文为害虫预测预报研究提供了一种可行的新方法。

**关键词:** 棉铃虫; 卵峰日; 预测预报; 框架; 径向基小波网络; 施密特正交化

中图分类号: Q968 文献标识码: A 文章编号: 0454-6296(2010)12-1429-07

## Forecasting model for the oviposition peak day in the second generation of *Helicoverpa armigera* (Lepidoptera: Noctuidae) based on radial basis wavelet network

ZHU Jun-Sheng<sup>1,2</sup>, ZHAI Bao-Ping<sup>1,\*</sup>, DONG Bao-Xin<sup>2</sup> (1. Department of Entomology, Nanjing Agricultural University, Nanjing 210095, China; 2. Plant Protection Station of Shandong Province, Jinan 250100, China)

**Abstract:** To improve the accuracy of crop pest forecasting, this paper introduced and applied radial basis wavelet network into the area of crop pest forecasting for the first time. The author modified the learning algorithms of radial basis wavelet network for application in pest forecasting. The scale and translation parameters were determined by the theory that time-frequency support of analyzed data sequence is covered with time-frequency support of radial basis wavelet functions. Based on the Euclidean distance between central vectors, the hidden-layer neurons are selected preliminarily. At case study, the investigation data of *Helicoverpa armigera* in Huimin, Shandong between 1966 and 1995 were used to establish the forecasting model of oviposition peak day in the second generation of *H. armigera* based on radial basis wavelet network, while the investigation data between 1996 and 2000 were used to test the model. The test results showed that the forecasting deviation of four years was less than three days and the forecasting deviation of one year was four days. The forecasting results proved satisfactory. This paper developed a new studying method for crop pest forecasting.

**Key words:** *Helicoverpa armigera*; oviposition peak day; forecasting; frame; radial basis wavelet network; gram-schmidt orthogonalization

如何提高害虫预测的准确率是农作物病虫害预测预报工作中的核心和热点问题之一。田间害虫种群的消长和影响害虫生长发育的外界因素共同组成了一个复杂的非线性系统, 因此, 采用非线性预测分析方法进行害虫的预测预报具有传统线性预测方法无法比拟的优点。小波神经网络 (wavelet neural

network, WNN) (Zhang and Benveniste, 1992; Baskshi and Stephanopoulous, 1993; Pati and Krishnaprasad, 1993) 是融合了小波分析和神经网络 2 种非线性理论的数学建模方法, 具有很强的非线性逼近能力。但是, WNN 在高维输入的情况下会产生“维数灾难”, 这是因为小波基函数会随着维数的增加而呈指数级的增

基金项目: 国家重点基础研究发展计划 (“973” 计划) 项目 (2006CB102007); 国家科技支撑计划项目 (2006BAD08A01)

作者简介: 朱军生, 男, 1972 年 11 月生, 山东威海人, 博士研究生, 研究方向为昆虫生态学, E-mail: mouse721112@yahoo.com.cn

\* 通讯作者 Corresponding author, E-mail: bpzhai@njau.edu.cn

收稿日期 Received: 2010-04-27; 接受日期 Accepted: 2010-10-27

长,导致网络结构和运算代价急剧增加。为此,很多学者(Zhang *et al.*, 1995; 吴耀军等, 1996; Zhang, 1997; 万建等, 2002)分别从不同的角度探讨了如何有效减少高维 WNN 的神经元数量以及降低运算代价,取得了一定的效果,但并未从根本上避免“维数灾难”。Kugarajah 和 Zhang (1995)构造了多维单尺度径向小波框架,给有效解决高维 WNN 所面临的问题开辟了一条新的途径。由于径向小波对维数不敏感,因此,以多维单尺度径向小波框架为基础的径向基小波网络便可以有效避开“维数灾难”问题。

目前,多维径向基小波网络在国内应用较少,吴清等(2003)将其应用到脑电逆问题求解,而在害虫预测领域尚无应用先例。害虫预测模型通常具有多维或高维输入的特点,适合于建立多维径向基小波网络,基于此,本文将多维单尺度径向基小波网络引入害虫预测领域,对算法进行了适当的调整和修改,使之适合于害虫预测方面的应用,并通过对 1996–2000 年山东惠民县 2 代棉铃虫卵峰日的预测来检验预测模型的效果。

## 1 建模方法

### 1.1 多维径向基小波网络结构

径向基神经网络(radial basis function neural network, RBFNN)是采用递减径向基函数做为隐含层激励函数的前馈神经网络,一个  $d$  维输入 1 维输出的 RBFNN 结构如图 1 所示。

网络输出为:

$$f(x) = \sum_{k=1}^n W_k \Phi(\|x - c_k\|) + b$$

其中,  $n$  为隐含层神经元的数量,  $W_k$  表示隐含




图 1 径向基神经网络的结构

Fig. 1 The structure of radial basis neural network

$X_i$ : 神经网络第  $i$  个输入变量 The  $i$ th input variable of neural network;  $C_i$ : 隐含层第  $i$  个神经元激励函数的中心向量 Central vector of stimulation function of the  $i$ th neuron in hidden layer;  $\Phi$ : 作为隐含层激励函数的径向基函数 Radial basis function as stimulation function of hidden layer;  $\|\cdot\|$ : 欧几里得范数 Euclidean norm;  $W_i$ : 隐含层第  $i$  个神经元与输出层之间的连接权值 Weight between the  $i$ th neuron of hidden layer and output layer;  $b$ : 输出层偏置量 Bias of output layer;  $\Sigma$ : 求和函数 Summation function;  $y$ : 神经网络输出 Output of neural network.

层第  $k$  个神经元与输出层的连接权值,  $\Phi(\cdot): \mathbb{R}^d \rightarrow \mathbb{R}$  作为隐含层激励函数的径向基函数,  $c_k \in \mathbb{R}^d$  表示隐含层第  $k$  个神经元激励函数的中心向量,  $b$  为输出层偏置量。

用多维单尺度径向小波基函数族取代 RBFNN 隐含层的激励函数就可以构造出多维单尺度径向基小波网络,伸缩步长为 2、位移步长为 1 的  $d$  维输入 1 维输出的径向基小波网络结构如图 2 所示。




图 2 多维单尺度径向基小波网络结构

Fig. 2 The structure of radial basis wavelet network based on multi-dimension and single-scaling

$X_i$ : 神经网络第  $i$  个输入变量 The  $i$ th input variable of neural network;  $m_i$ : 尺度参数 Scale parameter;  $n_i$ : 位移向量 Translation parameter;  $\Phi$ : 径向小波函数 Radial wavelet function;  $\|\cdot\|$ : 欧几里得范数 Euclidean norm;  $W_i$ : 隐含层第  $i$  个神经元与输出层之间的连接权值 Weight between the  $i$ th neuron of hidden layer and output layer;  $b$ : 输出层偏置量 Bias of output layer;  $\Sigma$ : 求和函数 Summation function;  $y$ : 径向基小波网络输出 Output of radial basis wavelet network.

网络输出为：

$$f(x) = \sum_{i=1}^s W_i \Psi(2^{-m_i}x - n_i) + b = \sum_{i=1}^s W_i \Phi\left(\frac{\|x - n_i 2^{m_i}\|}{2^{m_i}}\right) + b$$

式中， $W_i$  为隐含层第  $i$  个神经元结点与输出层的连接权值， $m_i$  为尺度参数， $n_i$  为位移向量， $\Phi$  为径向小波函数， $\Psi$  为径向小波函数的多维形式， $b$  为输出层偏移量， $s$  为隐含层神经元结点数量。

本文中的径向小波函数采用文献 (Kugarajah and Zhang, 1995) 中提到的墨西哥草帽函数 (Mexican Hat, Mexh)。

1.2 建模步骤

普通 RBFNN 的训练过程分为 2 步：第 1 步为无教师学习，确定训练输入层与隐含层间的权值；第 2 步为有教师学习，确定训练隐含层与输出层间的权值和偏移量。径向基小波网络的训练过程与普通 RBFNN 基本相同，但是算法不一样。吴清等 (2003) 详细探讨了径向基小波网络的学习算法，本文作者对其中不适合于害虫预测应用的具体实现过程进行了改进，建立了径向基小波网络害虫预测模型的训练算法，包括以下 3 步：

第 1 步 (Step 1)：确定尺度参数  $m$  和位移参数  $n$  的取值范围，初步得到隐含层神经元的构成。

从图 2 可以看出，要确定隐含层神经元、求出输入层与隐含层连接权值，必须先确定尺度参数和位移向量的取值，吴清等 (2003) 根据奈奎斯特采样定理来确定尺度参数的取值范围，而对于害虫预测应用来说，调查数据本身就是离散数据，所以无

法通过样本数据的采样间隔来确定尺度参数。本文作者对其进行了改进，提出采用时域和频域交叉、覆盖的方法，具体来说，就是在建立预测模型时，作为隐含层激励函数的小波基函数的时域和频域支撑区间至少能够覆盖到 1 个样本点，从而对未知映射的估计过程产生贡献。改进算法中的关键点是分析确定所有输入因子的周期频率变化范围，可采用带宽参数为 1、中心频率为 1 的 Morlet 复小波分析确定，分析方法参考王文圣等 (2003) 的方法。

第 2 步 (Step 2)：在每一个尺度空间中挑选能较好地对样本进行解释的小波基函数，进一步筛选第 1 步得到的隐含层神经元。

第 3 步 (Step 3)：用施密特逐步正交化方法去掉冗余的隐含层神经元，求解最佳小波基子集，同时完成网络训练。

本研究全部数据运算采用 Matlab 数值分析软件编程完成。

2 实例分析

2.1 实例资料和数据处理

实例模型为利用气象因素预测 2 代棉铃虫卵量峰值日期 (简称卵峰日)。2 代棉铃虫虫情资料来源于山东省农作物病虫预测预报观测数据集，采用的是山东惠民县 1966 - 2000 年 2 代棉铃虫发生期实况汇总数据；气象资料来源于山东省气象局 1966 - 2000 年逐日降水资料、逐日气温资料、逐旬平均气温资料、逐月平均气温资料、逐旬平均降水资料、逐月平均降水资料。其中，1966 - 1995 年 30 年的

表 1 山东惠民县 2 代棉铃虫卵峰日径向基小波网络模型的输入变量和输出变量  
Table 1 The inputs and outputs for radial basis wavelet network model for the oviposition peak day in the second generation of *Helicoverpa armigera* in Huimin, Shandong

代号 Symbol		意义 Meaning
输入变量 Input variables	I1	4 月中旬平均气温 Average temperature of middle April
	I2	4 月下旬平均气温 Average temperature of late April
	I3	5 月平均气温 Average temperature of May
	I4	6 月上旬平均气温 Average temperature of early June
	I5	6 月中旬平均气温 Average temperature of middle June
	I6	4 月中旬降水量 Rainfall of middle April
	I7	4 月下旬降水量 Rainfall of late April
	I8	5 月降水量 Rainfall of May
	I9	6 月上旬降水量 Rainfall of early June
输出变量 Output variable	Output	2 代棉铃虫卵峰日 Oviposition peak day of the second generation of <i>Helicoverpa armigera</i>

模型输出变量为 2 代棉铃虫卵量峰值日期，把 5 月 31 日作为基准值 0，其他日期按步长值 1 依次增减。The output variable of model is the oviposition peak day of the second generation of *H. armigera*. May 31 was taken as the zero base value and the other date changed with each day as step 1.

实况资料作为模型训练样本, 1996–2000 年 5 年的实况资料作为模型测试样本, 用来检验模型效果。

本研究选择了 9 个气象因子作为模型的输入, 模型输出为 2 代卵峰日 (以 5 月 31 日为 0, 其他日期依次类推) (表 1)。

为了保证良好的计算性能, 降低运算的复杂度, 对样本数据做归一化处理, 处理原则是:

$$\text{data} = \frac{\text{original} - \text{location}}{\text{scale}}$$

其中, original 为原始数据, location 为每一变量样本数据中的最小值, scale 为样本数据的最大值

减去最小值。

## 2.2 数据分析和建模

首先, 根据时域和频域覆盖的原则来确定径向基小波函数伸缩参数和位移向量的取值。模型输入因子的样本数据经过归一化处理后, 所有因子的样本数据都在 0 到 1 之间变动, 因此, 所有输入因子的时域支撑范围都是  $[0, 1]$ 。

利用 Morlet 复小波进行小波变换, 分别计算 9 个输入因子的小波方差, 并绘制各因子的小波尺度方差图 (王文圣等, 2003)。

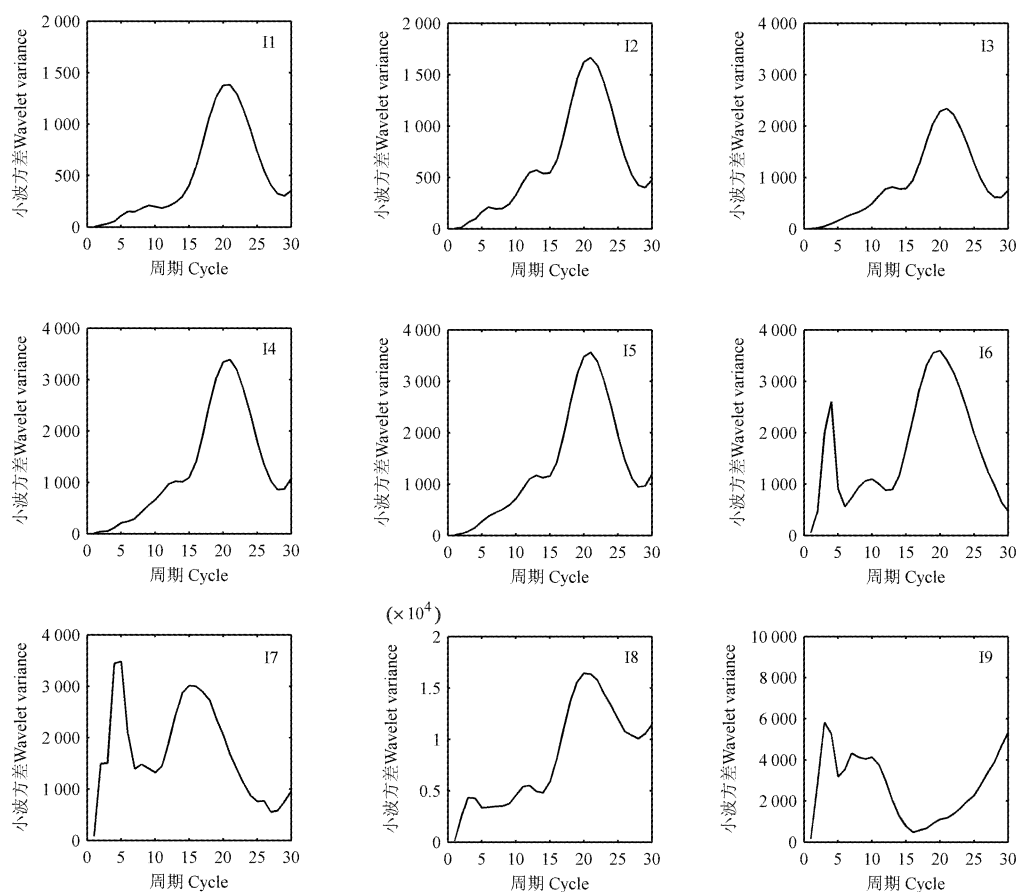


图3 输入变量小波方差图

Fig. 3 Wavelet variance figure of input variables

11–19 所代表意义同表 1。The meaning of 11–19 is the same as in Table 1.

通过分析各因子小波尺度方差图, 可以得到 9 个自变量输入因子的周期范围和相应的频率变动范围, 取各自变量输入因子频率变化范围的并集, 得到  $\left[\frac{2\pi}{25}, \frac{2\pi}{3}\right]$ 。

Mexh 函数的频域有效支撑范围可根据频率域

能量集中的原理 (张邦礼等, 1995) 来确定, 本研究取占总能量 99.9% 的区域作为母小波函数有效频域支撑范围, 为  $[0, 3]$ 。径向基神经网络中的径向基函数必须是正定的 (Buhmann, 1998), 径向基小波网络中的 Mexh 小波函数也必须满足这一条件, 因此, 本文中的 Mexh 母小波函数时域支撑范围确

定为 $[-1,1]$ 。伸缩步长为 2、尺度参数为  $m$ 、位移步长为 1、位移参数为  $n$  的 Mexh 小波函数族的时频支撑可以表示为：

$$Q_{m,n}=[2^m(-1+n),2^m(1+n)]\times[0,3\times2^m]$$

根据 Mexh 小波函数的频域支撑需要与输入因子频率变化范围相互覆盖或互相交叉的原理，则  $3\times2^{-m}>2\pi/25$ ，可求得  $m<3.577$ ，因为  $m$  为整数，所以  $m$  最大为 3。而由于 Mexh 小波函数正频域最小为 0，则实际上尺度参数  $m$  可以取为任意比 3 小的整数(包括 0 和负整数)。但是，对于尺度参数  $m$  范围的确定，需要以最小的范围能够覆盖因子频率范围为原则，所以对于尺度参数最小值的确定采用以下计算方法： $3\times2^{-m}=2\pi/3$ ，则  $m=-0.518$ ，因此尺度参数  $m$  最小为 0，尺度参数  $m$  的取值范围确定为 $[0,3]$ ，即尺度参数可取值为：0, 1, 2, 3。

当尺度参数  $m$  为 0 时，为了使 Mexh 小波函数族时域支撑能够完全覆盖输入因子时域支撑范围，必须满足下式：

$$-1+n>0,1+n<1$$

因此，尺度参数  $m$  为 0 时，位移参数取值范围为 $[0,1]$ ，由于位移步进为 1，则位移参数取值为 0 和 1。由于各维输入因子都经过了归一化处理，变动范围一致，所以，各维位移参数取值相同，都为 $[0,1]$ 。同理，可以求得尺度参数为 1, 2, 3 时，位移参数取值也为 $[0,1]$ 。

建模第 2 步是隐含层神经元的初步筛选。根据上一步所求得的位移参数的取值，不同输入维的位移量可以组成不同尺度下隐含层神经元激励函数的中心向量，每一个中心向量都对应着相应的隐含层神经元，这样获得的初始神经元数量在高维的情况下会比较庞大，因此，我们需要在保证能够完全覆盖数据信号时频空间的基础上精简基函数的数量，减少基函数的冗余性。

同一尺度参数下，两个基函数的中心向量之间欧式距离如果过小，我们认为 2 个基函数相似，则它们从样本数据中提取的信息也十分相似，可以只取其一。本例中，经过第 1 步运算，伸缩参数为 0, 1, 2 和 3 时，分别可以组合出 512 个中心向量。根据备选向量的多少，本例设定当 2 个中心向量之间的欧式距离小于 0.34 时，则表示由两中心向量组成的基函数相似，可以排除掉 1 个基函数。经过筛选，从 2 048 个基函数中初步筛选出 1 024 个向量。

最后，将 30 个训练样本输入，采用自适应正交投影算法进行网络学习训练，最终将隐含层神经元数量确定为 30 个，并计算出隐含层与输出层连接权值以及输出层偏移量。

至此，我们最终构造了一个具有 30 个隐含层神经元节点、9 维输入、1 维输出的径向基小波网络，利用 1996-2000 年 5 年的实际监测数据对网络模型进行检验，表 2 给出了检验结果，模型预报效果令人满意。

表 2 模型输出与发生实况比较  
Table 2 Comparison between the outputs of model and the real results

年份 Year	标准化输入因子 Standardized input factors									输出 Output	转化为日期 Date of forecasting	实况资料 Real date
	I1	I2	I3	I4	I5	I6	I7	I8	I9			
1996	0.153	0.727	0.445	0.513	0.495	0	0.097	0.030	0.006	0.560	6/26	6/26
1997	0.501	0.525	0.134	0.029	0.930	0	0.210	0.482	0.002	-0.075	6/19	6/21
1998	1.000	0.463	0.221	0	0.607	0	0.313	0.967	0.221	-0.082	6/19	6/20
1999	0.689	0.581	0.253	0.789	0.518	0.193	0.078	0.545	0.065	0.714	6/28	6/24
2000	0.614	0.568	0.292	0.440	1.000	0.133	0.011	0.134	0.004	-0.083	6/19	6/22

I1~I9 所代表意义同表 1，所有变量均经过标准化处理，模型输出同样为标准化值，模型输出值再经过反标准化处理并加上基准值 5 月 31 日后得到预测日期，反标准化公式：Forecasting date = output  $\times$  (31 - 20) + 20. The meaning of I1 - I9 is the same as in Table 1. All input variables were processed by standard treatment and the output of model was standard value too. Date of forecasting was gotten as a result of the sum of output anti-standardized and the base value May 31. Anti-standardized formula: forecasting date = output  $\times$  (31 - 20) + 20.

4 结论与讨论

径向基小波网络作为一种融合 WNN 和 RBFNN 的神经网络,兼具 WNN 逼近能力强 (Zhang and Benveniste, 1992; 李力和方华京, 2000) 和 RBFNN 训练速度快、不存在局部最优(周俊武等, 2001; 苏小红等, 2006)的优点,同时,克服了 WNN 在高维输入时所产生的“维数灾难”问题,大大简化了高维 WNN 的算法。对本例而言,若采用张量积的形式构建多维小波基,则在达到同样的精度下,建立 WNN 所需要的权值数目是以指数倍  $N^9$  ( $N$  是指对一维函数逼近时所需要的权值数目)的规模来衡量的,即使  $N$  是个很小的整数,所需要的权值数目也将很庞大,这也是 WNN 多用于一维或低维函数逼近的原因,而本文采用的径向基小波网络在 9 维输入的情况下最终只需要 30 个隐含层神经元即可完

成建模,极大地缩减了模型的规模。

农作物病虫害的发生和危害作为一种生态系统,具有复杂的非线性特点,因此常用的统计预测在预测精度上难以达到满意的效果,小波网络结合了小波变换和神经网络 2 种非线性理论,在模拟非线性系统上具有一定的优势。表 3 是基于误差反向传播的神经网络 (back-propagation neural network, BPNN) 和 RBFNN 对本例的预测结果,2 种神经网络都采用 3 层结构,BP 网络隐含层结构分别设定为 18, 19, 20 和 30 个神经元,RBFNN 的 spread 参数取值为 1.5。将表 3 与表 2 对比后发现,针对同样数据进行建模,径向基小波网络的预测精度要高于 BPNN 和 RBFNN。在建立的 4 种 BPNN 中,预测精度最高的是隐含层具有 19 个神经元的 BPNN,而 RBFNN 和径向基小波网络一样都具有 30 个隐含层神经元,这意味着径向基小波网络继承了普通 RBFNN 所具有的结构比 BPNN 略复杂的特点。

表 3 BPNN 和 RBFNN 预测结果  
Table 3 Forecasting of BP network and RBF network

年份 Year	BPNN				RBFNN	实况资料 Real date
	18 神经元	19 神经元	20 神经元	30 神经元		
	Eighteen neurons	Nineteen neurons	Twenty neurons	Thirty neurons		
1996	6/26	6/24	6/22	6/22	6/24	6/26
1997	6/23	6/22	6/24	6/28	6/22	6/21
1998	6/22	6/22	6/26	6/28	6/23	6/20
1999	6/27	6/24	6/26	6/23	6/29	6/24
2000	6/26	6/25	6/25	6/26	6/19	6/22

BPNN: 基于误差反向传播的神经网络 Back-propagation neural network; RBFNN: 径向基神经网络 Radial basis function neural network; 表中日期(月/日)(除最后一栏)为每种模型对 1996–2000 年山东惠民县 2 代棉铃虫卵峰日预测结果。The dates (month/day) (except the last column) in the table are the forecasting results of oviposition peak day of the second generation of *Helicoverpa armigera* between 1996 and 2000 in Huimin, Shandong, China.

不论是统计预报模型,还是神经网络等非线性预报模型,都是在若干年发生实况监测数据的基础上进行总结、归纳,从而得出发生特点,进而建立模型,因此,模型的建立要求历史数据越多越好。历史实况数据越多,模型越能够总结出病虫害发生的真实特点,从而模型的准确率越高。

病虫害的发生受多种因素影响,包括气象条件、病虫基数、作物长势和天敌等因素,因此,如何选取模型的输入因子是建立模型时要面对的首要问题。生态系统内部各因素间具有复杂的相互关系,所以,仅仅依据相关系数或偏相关系数等统计

学上的相关理论来判断和选择输入因子是狭隘的相关理论,而非线性相关理论在目前尚未有较合理的计算方法,因此如何确定模型输入自变量和输出因变量之间的非线性相关性也是以后需要着重研究的问题。本文在研究过程中,也曾尝试过利用小波分解得到的小波系数来计算两因素间的相关性,以后可以做深入的研究。

参 考 文 献 (References)

Baskshi BR, Stephanopoulous G, 1993. Wave-net; a multi-resolution, hierarchical neural network with localized learning. *Transactions of the American Institute of Chemical Engineers*, 39(1): 57–81.

- Buhmann MD, 1998. Radial basis functions on compact support. *Proceedings of the Edinburgh Mathematical Society*, 41: 33–46.
- Kugarajah T, Zhang Q, 1995. Multidimensional wavelet frames. *IEEE Transactions on Neural Networks*, 6(6): 1552–1556.
- Li L, Fang HJ, 2000. WNNs' approximate ability and improvements of Thau theorem. *Control and Decision*, 15(5): 561–564, 568. [李力, 方华京, 2000. 小波神经网络逼近能力及 Thau 定理推广. 控制与决策, 15(5): 561–564, 568]
- Pati YC, Krishnaprasad PS, 1993. Analysis and synthesis of feedforward neural networks using discrete affine wavelet transformations. *IEEE Transaction on Neural Network*, 4(1): 73–75.
- Su XH, Hou QX, Ma PJ, Wang YD, 2006. Hybrid learning algorithm for RBF neural network. *Journal of Harbin Institute of Technology*, 38(9): 1446–1449. [苏小红, 侯秋香, 马培军, 王亚东, 2006. RBF 神经网络的混合学习算法, 38(9): 1446–1449]
- Wan J, Xu DM, He YY, 2002. Multidimensional wavelet networks based on a tensor product structure. *Control Theory & Applications*, 19(3): 381–386. [万建, 徐德民, 贺昱曜, 2002. 基于张量积结构的多维小波网络. 控制理论与应用, 19(3): 381–386]
- Wang WS, Ding J, Heng T, Xiang HL, 2003. Wavelet analysis for the diagnosis of period and jump in hydrological time series. *Geotechnical Investigation & Surveying*, 31(1): 32–35. [王文圣, 丁晶, 衡彤, 向红莲, 2003. 水文序列周期成分和突变特征识别的小波分析法. 工程勘察, 31(1): 32–35]
- Wu Q, Shen XQ, Yan WL, 2003. A multi-dimensional wavelet network construction algorithm. *Chinese Journal of Computers*, 26(9): 1206–1210. [吴清, 沈雪勤, 颜威利, 2003. 一种多维小波网络的构造性算法. 计算机学报, 26(9): 1206–1210]
- Wu YJ, Tao BQ, Yuan SF, 1996. B-spline wavelet neural network. *Pattern Recognition and Artificial Intelligence*, 9(3): 228–233. [吴耀军, 陶宝祺, 袁慎芳, 1996. B 样条小波神经网络. 模式识别与人工智能, 9(3): 228–233]
- Zhang BL, Li YG, Cao CX, 1995. Construction of wavelet neural networks and its robustness analysis of learning algorithm. *Journal of Chongqing University (Natural Science Edition)*, 18(6): 88–95. [张邦礼, 李银国, 曹长修, 1995. 小波神经网络的构造及其算法的鲁棒性分析. 重庆大学学报(自然科学版), 18(6): 88–95]
- Zhang J, Walter G, Miao Y, Lee W, 1995. Wavelet neural networks for function learning. *IEEE Transaction on Signal Processing*, 43(6): 1485–1496.
- Zhang QH, 1997. Using wavelet networks in nonparametric estimation. *IEEE Transactions on Neural Networks*, 8(2): 227–236.
- Zhang QH, Benveniste A, 1992. Wavelet networks. *IEEE Transactions on Neural Networks*, 3(6): 889–898.
- Zhou JW, Sun CY, Wang FL, 2001. Study and implement of radial basis function neural network. *Mining & Metallurgy*, 10(4): 71–75. [周俊武, 孙传尧, 王福利, 2001. 径向基函数(RBF)网络的研究及实现. 矿冶, 10(4): 71–75]

(责任编辑: 袁德成)